

Real-time quality control using interactive vision : a theoretical and practical approach to interactive sensing and classification

Citation for published version (APA):

Westra, R. L. (2001). *Real-time quality control using interactive vision : a theoretical and practical approach to interactive sensing and classification*. [Doctoral Thesis, Maastricht University]. Datawyse / Universitaire Pers Maastricht. <https://doi.org/10.26481/dis.20011129rw>

Document status and date:

Published: 01/01/2001

DOI:

[10.26481/dis.20011129rw](https://doi.org/10.26481/dis.20011129rw)

Document Version:

Publisher's PDF, also known as Version of record

Please check the document version of this publication:

- A submitted manuscript is the version of the article upon submission and before peer-review. There can be important differences between the submitted version and the official published version of record. People interested in the research are advised to contact the author for the final version of the publication, or visit the DOI to the publisher's website.
- The final author version and the galley proof are versions of the publication after peer review.
- The final published version features the final layout of the paper including the volume, issue and page numbers.

[Link to publication](#)

General rights

Copyright and moral rights for the publications made accessible in the public portal are retained by the authors and/or other copyright owners and it is a condition of accessing publications that users recognise and abide by the legal requirements associated with these rights.

- Users may download and print one copy of any publication from the public portal for the purpose of private study or research.
- You may not further distribute the material or use it for any profit-making activity or commercial gain
- You may freely distribute the URL identifying the publication in the public portal.

If the publication is distributed under the terms of Article 25fa of the Dutch Copyright Act, indicated by the "Taverne" license above, please follow below link for the End User Agreement:

www.umlib.nl/taverne-license

Take down policy

If you believe that this document breaches copyright please contact us at:

repository@maastrichtuniversity.nl

providing details and we will investigate your claim.

Summary

Chapter 1 INTRODUCTION

The subject of this study is the automatic control of printing processes by means of images of the prints. This places our study in the field of 'Computer Vision'. This is a rapid developing area, caused by scientific and technological innovations. This development is driven by a steady decrease of price, combined with a ditto increase of performance, both of hardware and software. Due to these developments, there is much interest from industry, and the number of practical applications grows continually.

Certain characteristics of human vision are relevant for our subject. Especially, the active way in which humans visually explore an unknown object is very inspiring for our approach. This 'active vision' is a close cooperation between eye and brain, in which the brain analyses and interprets incoming images. From this interpretation of the image grows a certain hypothesis about the image, and from this certain expectations. Based on these assumptions, the brain selects another relevant part of the image. Thus, the eye is aimed at this area, and the image is analysed conditional to the actual hypothesis. In practice, this mechanism converges to the right conclusion within a 'blink of the eye'. In case of visual illusions the system is not able to converge to a solution, and we can as it were catch this mechanism in action. Based on this biological interpretation, we model the automatic analysis of prints in a similar way; as an interaction between a reasoning process that generates hypotheses and expectations regarding the image, and image-analysis techniques that perform and process requested sensing operations at certain identified locations of the image. The reasoning process thereby governs the position and the nature of the measurements. This process causes a 'real-time' diagnosis of the observed object, while only a fraction of all possible measurements is performed. This mechanism forms the central part of this thesis, and is treated in the Chapters 6, 6, and 7.

Another inspiration from human vision concerns its ability to recognise textures. For humans, a small fragment of a texture, like textile, wood, stone, or paper suffices for an instantaneous recognition. Equipped with this capability, humans can promptly identify defects or imperfections in prints. We shall model this ability with the use of the new field of 'fractal wavelet-analysis'. This is described in Chapter 3.

Innovative subjects in this study include:

1. interactive classification based on the mechanism of active vision,
2. fractal wavelet analysis of print-pattern independent defect recognition,
3. geometrical transformations that represent images one-to-one on an interval or rectangle,
4. an automatic clustering method that is suitable for fast, 'unsupervised' partitioning of many-parameter data with not well-separated classes. This is relevant for our context of computer vision.

Chapter 2 THE ANALYSIS OF PRINTED IMAGES

Main objective of this Chapter is to transform images (in our case CCD-images) of prints into one general representation. This frees us from all details of the print-pattern, called the *template*, that may vary in printing processes.

First we describe the structure and characteristics of prints. We define images of prints as continuous patterns of grey-scales. The *print-border* is the curve that separates the *printed* from the *not-printed* area. Most printing defects occur in specific areas relative to the print-border; *near* or *far from* the print-border, *inside* or *outside* printed areas. In this way four different types of area types can be distinguished, called *print-contexts*. The template is the print-pattern. Our ultimate objective is *template-free* defect-recognition and print-quality control. By subtracting the template from the image, we obtain a direct impression from the printing defect, both its characteristic shape as its distribution over the print-contexts.

A printing-defect is characterised by its shape, texture, and greyscale-distribution. These parameters can be linked to the features of the printing-defects. These features are expressed in the so-called *feature-parameters*. These quantify the degree in which the feature is present. In this way, a printing-defect can be represented as a point in a *feature-space*. The position of this point in space determines to which defect-class it belongs, independent of the applied template.

The central subject of this Chapter concerns the transformation of printed images into one general representation. This representation makes the image independent of the template, and thereby enables template-free defect-classification. Starting point of this transformation is the *Euclidean Distance Transform* (EDT), that gives the distance from a point to a given geometric set. An addition to the EDT concerns the location of the point *inside* or *outside* the printed area. We define the *print-depth* of a point in an image as the minimal Euclidean distance of that point to the print-border. The sign of the print-depth is *positive* if the point is *outside*, and *negative* if the point is *inside* the print. Using the print-depth, we can define a one-dimensional representation of printed images. This representation gives the normalised, cumulative intensity of all faults at a certain print-depth. Therefore, this transformation is called the 'Cumulative Intensity Distribution', short CID. This template-independent transformation enables a number of analyses, such as generalised moments, filters, deconvolution, or spectral analysis. Two examples are given of representations based on the CID that are able to separate specific clusters of defect classes. These representations are therefore suitable for pre-classification. Next, we try to construct a two-dimensional analogon of the CID. However, it appears to be impossible to construct continuous two-dimensional representations. The problems are analogous to map-projections: it is not possible to construct continuous flat representations of a globe. Locally, continuous representations are possible, or, consequently, as a collection of local maps. We define a transformation, called two-dimensional Intensity Map (2DI-map), that is locally not-continuous, but does possess attractive local congruency characteristics. In this way, defects can sustain their characteristic form. With the 2DI-map arbitrary prints are represented in a rectangle, with above the printed, and below the non-printed area. More serious than all mathematical complications of the 2DI-map is the discrete nature of the CCD-images. This causes Moiré-like segmentation, that seriously inhibit the practical use of the 2DI-map.

As a consequence of the representations discussed in this chapter, especially the feature-space representation and the CID-transform, we can now represent all kinds of printings as points in high-dimensional parameter-spaces. This allows us in later chapters to concentrate on clustering and classification techniques that are suitable for these kinds of spaces, without being concerned with the details of the template employed.

A separate appendix describes the determination of feature parameters from printing defects.

Chapter 3 ANALYSIS AND CLASSIFICATION USING FRACTAL WAVELET ANALYSE

In recent decennia much attention has been devoted to objects that reveal new details at each scale of magnification. These, so-called 'fractal' sets, appear to be relevant for the description of natural objects and physical processes. The main motivation in this Chapter is to investigate whether the characteristic features of printing defects can be expressed in a fractal representation. To that end we employ the 'multi-fractal' formalism, that provides a more appropriate, but also more complex description. In the multi-fractal formalism a set is represented by a mass or probability distribution. We can interpret the greyscales of an image as such a distribution. With methods from the macro canonical ensemble theory, we are able to calculate an entire spectrum of fractal characteristics of the set, including the fractal dimension, the entropy, and the auto-correlation. This spectrum of fractal properties is called the *Generalised Fractal Dimension* (GFD).

A practical problem concerns the determination of the GFD. Conventionally, a set is covered with a collection of hyper-boxes, and certain scaling properties of this covering is studied as the side of these hypercubes approaches to zero. Not only it is difficult to construct such a covering of most sets, it has also been demonstrated that many disadvantages are connected to this method. For instance, it can be shown that this method systematically underestimates the fractal dimension for dimensions larger than 2.6.

In this respect another and also recent formalism is helpful: wavelets and Multi Resolution Analysis (MRA). Wavelets are, like the name implies, small waves: they have integral zero (hence 'wave'), and a small compact support (hence wave-let). Similar to Fourier-analysis it is possible to represent images as (infinite) summations of wavelets. MRA offers an elegant method for this decomposition. The price paid for this elegance is that besides the spectral components also the spatial components must be determined, causing a doubling of the number of coefficients. MRA concentrates at each scale of magnification on those parts of the set where this scale is especially relevant. But this characteristic is exactly what is needed to cover fractal sets with hypercubes. Therefore we can see wavelets as a kind of generalised hypercubes, and therefore MRA as a generalised method for covering fractal sets. For this reason, wavelets are especially suited for the analysis of fractal sets. In recent years this approach has been refined, especially by Mallat and Hwang. This has led to the development of the 'Wavelet-Transform Modulus Maxima' (WTMM) method. With the WTMM-method the GFD of an object can be computed efficiently. This method has been recently applied successfully for the analysis and classification of different types of textures.

In Chapter 3 all these formalisms are briefly discussed, and where necessary explained with an example. First, 'traditional' Fourier-analysis is applied. From this analysis global power-laws can be computed, but no fractal dimensions. Therefore, the multifractal formalism is applied to the analysis of scan-profiles and images of printing defects. With this approach it is possible to transform a printing-defect into a collection of numbers, the GFD. This collection can be seen as a specific kind of 'feature-vector'. In this representation, it is possible to significantly separate many printing defect classes. There are, however, many practical problems to this method, including the excessively long computation times, and the digital nature of the images, which allow only a limited degree of magnification.

The attractive side of this representation is that it 'strong' template-free, i.e. in no way assumes any knowledge of the applied template – where we assume that the template itself is no fractal. Moreover, it is – in principle – possible to relate the GFD of the image to the underlying physical-chemical printing process. the printing-defects are caused by a combination of rheological, mechanical, electro-dynamical, and chemical processes, which therefore also determine the GD of the resulting pattern. Knowledge of this mechanism would

enable to estimate the relevant process-parameters from the GFD of the CCD-image, and thus to correct the process. At the moment, however, such an idea is totally infeasible.

We conclude that the idea of multifractal wavelet-analysis for classification of printing-defects has a potential for future use, but at the moment is not realistic.

In the cause of this chapter we also introduce an original generalisation of MRA, called the *Global Wavelet Decomposition*.

Chapter 4 CLUSTERING METHODS FOR WEAKLY-SEPARATED MANY-PARAMETER CLASSES

As a result of the definitions provided in Chapters 2 and 3, we can now represent an image from a printing-defect as a single point in a high-dimensional 'feature-space'. In this way collections of points group together in classes, the printing-defect classes. Many of these classes are found to be weakly separated, as they overlap significantly. Moreover, it seems that there is a large number of clusters in the data. This rises the question, which would be the best 'clustering' of the data in meaningful clusters. Perhaps a more significant taxonomy of defects is possible than provided by human experts. Another major motivation is the *interactive* classification-algorithm, discussed in Chapter 5, that requires only a small part of the feature-space.

In this Chapter several clustering paradigms are tested on their suitability for our feature-space. Direct clustering and classification of images using artificial neural networks appears to be computationally complex. The neural nets necessary for this application require an exceedingly high number of parameters. This would require an unrealistic number of empirical data, in order to train these parameters.

Accordingly, we study 'fuzzy clustering'. Techniques like Fuzzy C-Means (FCM) are 'unsupervised' (i.e. the training set is unlabeled) clustering techniques. We propose an addition to FCM, by replacing the spheroidal FCM-memberships-functions by ellipsoidal functions. This represents a better approximation of the local class-conditional metric. We call this method Fuzzy Multi-Variate clustering (FMV). This results in a clustering that provides equivalent partitions, but converges faster to the final result. Therefore, FMV is also more appropriate for high-dimensional spaces than FCM.

A large disadvantage of many clustering-methods, including FCM and FMV, is that they require some ad-hoc assumptions on the number of distribution of the clusters in feature-space. Therefore, we propose an automatic clustering algorithm, called *iterative FMV cluster analysis*, based on FMV, that can autonomously determine the number of significant classes in the data, by means of successive fusion and decomposition.

Finally, we apply clustering techniques to two representations that are based on the CID-transformation from Chapter 2. In the first case we show the SOM-clustering technique can be used to estimate the intensity of a defect from a simple model for two kinds of printing defects. In the second case we show how iterative FMV cluster analysis can be used for partitioning a CID-based representation, which therefore is valuable for pre-classification.

Chapter 5 INTERACTIVE CLASSIFICATION OF NUMEROUS WEAKLY SEPARATED MANY-PARAMETER PROTOTYPES WITH NOISE

Now we have reduced printing-defect analysis to the classification of an actual measurement expressed as a set of feature-parameters to one of a set of previous defined defect-classes. This could imply that first all possible measurements should be performed, which afterwards is straightforwardly assigned to the defect-class that corresponds to the identified part of feature-space. This would make classification very time-consuming and computationally demanding. Moreover, it is mostly unnecessary to perform all measurements, because during the process it has already become clear which defect-class occurred. Inspired by the mechanism of 'active vision' by humans, we opt for a different approach. In this Chapter, we propose an interactive method for simultaneous sensing and classification. We call this 'Interactive Classification'. The most vital problem here, is to – based on the present set of measurements and resulting hypotheses – select the 'best' possible candidate for the next measurement. The approach that we adopt is based on functional optimisation. We define a number of functionals, based on class-separation. First, however, we must define a useful metric in feature-space. The most frequent applied distance-measure is the so-called 'Mahalanobis-distance' (MD). However, the MD is non-symmetric for interclass-distances: in general: $\text{distance}(\text{klasse1}, \text{klasse2})$ is not equal to: $\text{distance}(\text{klasse2}, \text{klasse1})$. therefore, we come with other propositions, like the 'geometric' distance. In the same sense, we define the 'relevance'; of a certain feature-parameter for a certain defect-class. With the use of these distance-measures, we can now construct functionals. Optimisation of these functionals leads to the feature-parameter that causes the largest separation of the classes, and thus the most useful measurement. By including the actual hypothesis – represented by the probability-distribution over the defect-classes – we make this process 'dynamic'. Thus, we select the feature-parameter for measurement that, given the current set of hypotheses, offers the best perspective to choose between competing hypotheses. In this respect it is important that during the reasoning process the weight of the actual hypotheses increases, for initially a hypothesis is more prone to error. This increase is controlled by the so-called 'dynamicity-exponent'.

Next, the problem of integrating large amounts of heterogeneous information is considered, such as qualitative and quantitative information. Our choice is to represent qualitative information as 'fuzzy' parameters. Therefore, we only have quantitative information. Defect-classes in our representation are modelled by 'Gaussian mixtures', i.e. as multivariate normal distributions. Much emphasis is devoted to the control of the reasoning process. Some 'static' and 'dynamic' termination criteria are defined. 'Dynamic' here means that the history of the iteration is involved in the decision to terminate. We find that in case of a termination-criterion with a constant threshold, an optimal value can be computed in the sense of a maximal success-rate with a minimal iteration-length.

All these subjects together form the ingredients for an integrated approach for simultaneous *sensing* and *classifying*, called: *InterActive Sensing and Classification* (IASC). Objective of IASC is the on-line classification of an object, based on selected sensor-readings. This method can be defined as an iterative algorithm, or as an iterated transformation in the space of hypotheses, where a sensing concerns 'just' one feature-parameter. For our assumption of a Gaussian mixture, this transformation can be further specified.

Of vital importance is the question of convergence and stability of the IASC-algorithm. For this reason, we first define some measures for its performance: the quality 'q' of a conclusion

(1 for explicit, and 0 for indefinite conclusions), the *success-rate* 's' of the algorithm (1 if the correct defect-class is identified, else 0), and the relative iteration-length 'T' (the number of performed measurements relative to the total number, so also in-between 0 and 1). As mentioned before, the actual hypothesis can be represented as a probability-distribution over the K possible defect-classes. The actual hypothesis can therefore be represented as a normalised vector \mathbf{p} in \mathbb{R}^K , and, in the scenario where the probability of the individual classes lies in the interval $[0,1]$, more specific as a point in a K -dimensional hypercube: $[0,1]^K$. The edges of this hypercube correspond with the individual defect-classes. Therefore, the whole *IASC*-iteration corresponds with a trajectory in this hypercube. The *IASC*-iteration is said to converge if this trajectory end in an edge. The actual *measurement*, however, is a single vector in feature-space. During the iteration the components of this – initially unknown – vector become known. The feature-space is partitioned in K cells, which corresponds with the K identified defect-classes.

The central conjecture in our approach is that if a measurement lies in a certain cell in feature-space, the *IASC*-iteration converges with a quality q to the defect-class associated to the cell, such that q is determined by the distance between the measurement and the centre of the cell. This distance is also a measure for the *relative noise* in the measurement.

Several approaches are pursued in order to proof this conjecture. In Section 5.6.5 it is demonstrated that the *IASC*-iteration is a contraction, because the Jacobian monotonously decreases to zero. All converging iterations are contractions. However, not all contractions correspond to converging iterations. For example, iterations with multiple or 'strange' attractors. In Section 5.6.6, three scenarios for the convergence are studied in more detail. (i) If the measurement coincides with the centre of a cell then the *IASC*-iteration converges to the correct conclusion. (ii) If the measurement lies very close to the centre of the cell, the *IASC*-iteration also converges. Here, close means: closer than the square root of the smallest eigen-value of the covariance-matrix of the associated defect-class. (iii) The measurement does not lie 'near' to a cell-centre. If the Euclidean distance to the cell-centre increases, there will be more feature-parameters for which this particular measurement lies closer to the centre of another cell-centre. These feature-parameters are therefore weakly separated, relative to the others, and have a low a-priori probability for selection in the functional parameter-selection that lies at the heart of the *IASC*-algorithm. Nevertheless, if the fraction of these 'wrong' parameters increases, the probability of a wrong conclusion increases also.

In Section 5.7, the dynamic properties of the *IASC*-iteration are studied in more detail. First, the evolution of the individual class- or state-probabilities are studied. Two simple observables are defined: the *final value*, and the *average increase* of the state-probabilities. By automatically clustering (NB: with *iterated FMV* from Chapter 4) a large number of observations, four primitive types of evolution are identified. These four types can be connected to the relative position of the clusters. *Near* clusters cause some 'confusion' in the evolution of state-probabilities during the iteration, and allow for a relatively late moment of changing the 'balance' of the hypothesis from one state to another. Some state-probabilities converge to a value somewhere in-between zero and one. This finding leads to a discussion of the role of *diffuse classes* and *mixed equilibria*. Mixed equilibria are points in feature-space that are 'undecidable'. Undecidable here means that the *IASC*-iteration does not converge to an explicit conclusion. In case of an infinite iteration, these are the points on the separatrix between two classes. Because of the finite nature of the *IASC*-iteration, points near to such separatrices will also be undecidable, especially for diffuse classes. Thus, the set of undecidable points are the vertices of a fuzzified Voronoi-partitioning based on the cell-centres.

The following sub-sections focus on the estimate and confidence-interval of the entire measurement-vector during the *IASC*-iteration. This allows for the calculation of the probability to reject the actual hypothesis based on a new measurement. It is shown that this probability decreases quasi-exponentially during the iteration.

Of major importance on the performance of the *IASC*-algorithm are the termination-criteria. These are studied in Section 5.7.5. With a *mean-field* approach, a theoretic model is obtained that predicts the relation between the average success-rate s and the relative iteration-time T . Finally, in Section 5.7.6 a number of models are proposed for the evolution of the dynamicality-exponent. These determine the influence of the actual hypothesis on the functional feature-parameter selection.

We conclude that the *IASC*-algorithm provides a framework for interactive classification, that under certain circumstances converges to the correct conclusion, while only a small fraction of all measurements is performed. This framework is not only applicable to Computational Vision, but in all cases where diagnosis and measurement concur, like in chemical analysis, medical diagnosis, and autonomous robots.

Chapter 6 NUMERICAL EXPERIMENTS WITH *IASC*

In this Chapter the *IASC*-algorithm is studied by means of a number of numerical experiments. This will increase our understanding, and allows us to compare it with other methods. Moreover, some theoretical predictions from Chapter 5 can be tested. In order to quantify the performance, we measure the success-rate s , quality q , and the relative iteration-time T . Indicators for the *complexity* of the classification-problem are the average normalised intra-class geometric distance $\langle d \rangle$, and the relative noise ν in the measurement – which is a measure for the normalised distance between the measurement and the defect-class cell-centre.

Control parameters for the *IASC*-algorithm are the applied optimisation-functional, the representation of the state-probabilities (in our case Gaussian), the development of the dynamicality-exponent, and the applied termination-criterion. As a measure for comparison, we regard two extremes: (i) exhaustively performing *all* measurements, and: (ii) *random* selection of feature-parameters. The conclusion of the analysis is that for overlapping classes ($\langle d \rangle < 1$) or for small to moderate noise ($\nu < 0.4$) the *IASC*-algorithm performs better than exhaustive or random parameter-selection. Also, some experiment is described of multi-criteria functionals.

Next, some models for the evolution of the dynamicality-exponent are tested. This reveals large differences between the scenario where the exponent is constant zero, and all others, but remarkably enough almost no difference in-between the other evolution-models.

Finally, several static and dynamic termination-criteria are compared. In Section 6.6.4 the theoretically predicted relation between success-rate and iteration-length for a constant threshold is verified, as well as the theoretically predicted optimal value for this threshold.

The general conclusion for interactive classification with *IASC* can be summarised concisely in terms of *class-overlap* and *relative noise*:

- medium overlap and medium noise: *all* methods work
- medium overlap and high noise: *IASC* is better than random / exhaustive selection
- severe overlap and medium noise: *IASC* is better than random / exhaustive selection
- severe overlap – high noise: *nothing* works.

Chapter 7 ON-LINE CONTROL OF PRINTING QUALITY USING COMPUTATIONAL VISION.

In this Chapter we return to our main topic; the quality-control of printing-processes. In this Chapter all ingredients of the previous Chapters are combined. This mainly concerns the results of the European research-project *IntelPadPrint*, in which framework this study is largely performed. After a short description of the objectives, composition, and eventually obtained results of this project, a description is given of the area of application: industrial padprinting processes for mass-production. In a separate Section the relevant feature-parameters for padprinting defects are discussed. Next, the two realised prototypes are considered.

The first prototype, called PT1, was based on scanning-analysis and a model for linear correlation between feature-parameters and defect-classes. A simple model controlled the spatial exploration of the CCD-image of a printed element for failures, and the eventual integration of all hypotheses. This iteration mostly converged within some hundred steps to a result. The average performance of this algorithm was $79 \pm 22\%$. In fact, this was a primitive predecessor of the *IASC*-algorithm.

The second prototype, PT2, was equipped with the *IASC*-algorithm (Chapter 5). It also employed the pre-classification method based on a CID-transformation of the image (Chapter 2). Some of the feature-parameters were computed using fractal wavelet analysis (Chapter 3). Moreover, the partition of feature-space was performed with *iterated FMV* (Chapter 4). An *intelligent camera system* (developed by the University of Birmingham) produced CCD-images of predominantly good quality. The evaluation of this system involved three levels: (i) the identification that a printing-defect has occurred, (ii) the mentioned pre-classification of the template-subtracted and upgraded CCD-image, and: (iii) the result of the *IASC*-algorithm. For images of sufficient quality, about 77% of the total, the performance amounted to: for (i) 99%, for (ii) (pre-classification): 97%, and for (iii) (*IASC*): 95%. The latter was determined largely by the efficiency of the feature-extraction.

The main conclusion regarding prototype PT2 is that *IASC* functions well, but that it is very sensitive to the image-quality. Therefore, in a practical application of this prototype the image-quality must be improved significantly.

The main conclusion of our thesis is that an approach based on interactive classification and fractal wavelet analysis provides a good framework for on-line print-quality control, but that more research is required to bring such a concept into industrial practice.

Samenvatting

Hoofdstuk 1 INLEIDING

Het onderwerp van deze studie is de automatische controle van drukprocessen middels afbeeldingen van de bedrukkingen. Dit plaatst deze studie in het gebied dat 'Computer Vision' heet. Dit vakgebied maakt een stormachtige ontwikkeling door, zowel vakinhoudelijk alsmede door de gestadig toenemende prestatie en dalende prijzen van hardware, en meer veelzijdige software. Door deze ontwikkelingen neemt het aantal toepassingen eveneens stormachtig toe, en is er sprake van grote interesse vanuit industrie en bedrijfsleven.

Voor ons onderwerp zijn een aantal eigenschappen van het menselijke gezichtsvermogen uitermate belangwekkend. Met name de actieve manier waarop mensen een object visueel verkennen is zeer inspirerend voor onze aanpak. Dit 'actieve zien' is een nauwe samenwerking tussen brein en oog, waarin het brein binnenkomende beelden analyseert en interpreteert. Uit deze interpretatie ontstaat een hypothese omtrent het beeld, en daaruit bepaalde verwachtingen. Gebaseerd op deze veronderstellingen selecteert het brein een ander relevant onderdeel van het beeld voor verdere analyse, waarop het oog op dit gebied gericht wordt, en het beeld vanuit de actuele hypothese wordt geanalyseerd. In de praktijk convergeert dit mechanisme binnen een 'oogwenk' naar de juiste conclusie. In geval van visuele illusies lukt het het systeem niet om te convergeren, en kunnen we dit mechanisme als het ware betrappen. Vanuit deze biologische inspiratie modelleren we de automatische analyse van bedrukkingen op een analoge wijze; als een interactie tussen een redeneer proces dat hypothesen en verwachtingen omtrent een beeld genereert, en beeldverwerkings-technieken die bepaalde locaties onderzoeken en daar enkele gevraagde metingen verrichten. Hierbij stuurt het redeneerproces de plaats en de aard van de metingen. Dit proces veroorzaakt een 'real-time' diagnose van het betrachte object, waarbij slechts een fractie van alle mogelijke metingen verricht wordt. Dit mechanisme vormt een centraal onderwerp van het proefschrift, en wordt behandeld in de hoofdstukken 5, 6 en 7.

Een andere inspiratie vanuit het visueel-cognitieve apparaat betreft het vermogen om 'texturen' te herkennen. Een afbeelding van een textuurfragment, b.v. hout, textiel, steen, huid, of papier, volstaat voor een instantane herkenning. Vanuit dezelfde vaardigheid kunnen mensen fouten of onregelmatigheden herkennen in b.v. bedrukkingen. We zullen deze vaardigheid trachten na te bootsen middels 'fractale wavelet-analyse', een recent opgekomen formalisme. Dit staat beschreven in hoofdstuk 3.

Vernieuwende onderwerpen in deze studie zijn onder meer:

1. interactieve classificatie gebaseerd op het mechanisme van 'actief zien',
2. fractale wavelet analyse van bedrukkingen voor bedrukkingsmotief-onafhankelijke fouterkenning,
3. transformaties die bedrukkingen op een eenduidige wijze afbeelden op een interval of rechthoek,
4. een automatische clusteringmethode, die geschikt is voor snelle, 'unsupervised' partitionering van veel-parameterdata met veel, slecht-gescheiden klassen. Dit is relevant in onze context, omdat wij precies met zulke parameterruimten te maken krijgen.

Hoofdstuk 2 DE ANALYSE VAN BEDRUKKINGSBEELDEN

Doelstelling van dit hoofdstuk is om beelden (in ons geval CCD-foto's) van bedrukkingen in één algemene vorm af te beelden, zodat we niet meer te maken hebben met allerlei details die per bedrukking kan variëren.

Allereerst betrachten we de structuur en eigenschappen van bedrukkingen. We definiëren afbeeldingen van bedrukkingen als continue patronen van grijswaarden. De *bedrukkingsrand* is de curve die *bedrukt* van *niet-bedrukt* gebied scheidt. De meeste soorten bedrukkingsfouten treden alleen op in bepaalde soorten gebieden; *nabij* of *ver weg* van de bedrukkingsrand, *binnen* of *buiten* het bedrukte gebied. Zodoende ontstaan vier gebiedstypen op een bedrukking, die we *printcontexten* noemen. De *templaat* is het patroon dat gedrukt moet worden. Onze uiteindelijke doelstelling is *templaat-onafhankelijke* foutherkenning en kwaliteitssturing. Door het beeld van de bedrukking over de templaats te leggen, en de twee beelden af te trekken, verkrijgen we een direct beeld van een eventuele bedrukkingsfout, zowel zijn karakteristieke vorm alsook zijn verdeling over de printcontexten.

Een bedrukkingsfout wordt gekarakteriseerd door zijn vorm, textuur, en grijsheidswaardenverdeling. Tal van eigenschappen van drukfouten kunnen hieraan worden gerelateerd. Deze eigenschappen worden weergegeven door de 'featureparameters'. De mate waarin de eigenschap voorkomt wordt hierbij weergegeven door een getalswaarde. Op deze wijze kan een drukfout als een punt in de 'feature-ruimte' worden weergegeven. De positie van een punt in deze ruimte bepaald tot welke drukfoutenklasse het behoort, ongeacht zijn templaats.

Het centrale onderwerp van dit hoofdstuk betreft de transformatie van bedrukkingen naar een algemene representatie. Ook deze representatie maakt de afbeelding onafhankelijk van de templaats, en maakt zodoende templaats-onafhankelijke foutclassificatie mogelijk. Uitgangspunt voor de transformatie is de Euclidische afstandstransformatie (EDT), die de afstand van een punt tot een verzameling geeft. Een aanvulling op de EDT betreft de positie van een punt *binnen* of *buiten* het bedrukte gebied. De afstand in een afbeelding van een bedrukking definiëren wij nu als de minimale Euclidische afstand tot een bedrukkingsrand, met *positief* teken *buiten*, en *negatief* teken *binnen* het bedrukte gebied. Deze afstandsmaat noemen we de 'bedrukkingsdiepte'. Middels de bedrukkingsdiepte kan nu een een-dimensionale transformatie op beelden van bedrukkingen worden gedefinieerd. Deze afbeelding geeft de (genormeerde) som van alle fouten op een bepaalde bedrukkingsdiepte. We noemen deze afbeelding de 'Cumulatieve Intensiteit Distributie', kortweg CID. Deze templaats-onafhankelijke afbeelding staat een aantal analyses toe, zoals gegeneraliseerde momenten, filteren of deconvolutie, of spectrale analyse. Twee voorbeelden worden gegeven van representaties gebaseerd op de CID, die in staat zijn verscheidene clusters foutklassen te scheiden. Deze representaties zijn derhalve geschikt voor preclassificatie.

Vervolgens trachten we een twee-dimensionaal analogon van de CID te construeren. Het blijkt echter niet mogelijk om een continue twee-dimensionale representatie te construeren. De problemen zijn analoog aan kaart-projecties: het is niet mogelijk om een continue vlakke representatie van een globe te construeren. Dit kan wel lokaal, of via een collectie van lokale kaarten. Wij definiëren een afbeelding, 2DI-map geheten, die inderdaad lokaal niet-continu is, maar wel aantrekkelijke lokale congruentie-eigenschappen heeft. Zodoende behouden fouten veelal hun karakteristiek vorm. Met de 2DI-map worden willekeurige bedrukkingen weergegeven in een rechthoek, met boven de centrale horizontale as het binnengebied, en daaronder het buitengebied van de bedrukking. Een veel groter probleem dan alle mathematische complicaties blijkt het discrete karakter van de CCD-foto's te zijn. Hierdoor ontstaan Moiret-achtige coupes, die verder gebruik van de 2DI-map voor classificatiedoeleinden ernstig beperken.

Door deze transformaties, met name de feature-representatie en de CID-transformatie, kunnen we nu alle soorten bedrukkingen weergeven als punten in parameterruimten. Hierdoor kunnen we ons in latere hoofdstukken concentreren op clustering- en classificatietechnieken in dit type parameterruimten, zonder ons te bekommeren om allerhande details van de templaet.

Een aparte en uitgebreide appendix is gewijd aan de bepaling van featureparameters voor bedrukkingsfouten. De reden hiervoor is dat in de praktijk snel heengelopen wordt over de problematiek om goede featureparameters te definiëren. Vaak is het niet goed mogelijk om deugdelijke algoritmen voor de kwantificatie van bepaalde kenmerkende eigenschappen te construeren. In dergelijke gevallen hebben alle verdere clustering- en classificatietechnieken ook weinig zin meer. In deze appendix wordt in detail een groot aantal featureparameters besproken, soms vergezeld van een evaluatie van de performantie.

Hoofdstuk 3 ANALYSE EN CLASSIFICATIE MIDDELS FRACTALE WAVELET ANALYSE

De laatste decennia is er veel aandacht voor objecten die op elke schaal van vergroting relevante details vertonen. Deze ‘fractale’ verzamelingen blijken van groot belang te zijn voor de beschrijving van fysieke objecten en fysische processen. Belangrijkste motivatie in dit hoofdstuk is om te onderzoeken of het karakteristieke uiterlijk van bedrukkingsfouten weergegeven kan worden middels een fractale beschrijving. Daarbij maken we gebruik van het ‘multi-fractale’ formalisme, dat een meer geschikte, maar ook meer gecompliceerde beschrijving verschaft. In het multifractaal formalisme wordt de verzameling gerepresenteerd middels een dichtheidsfunctie. Met behulp van methoden uit de macrocanonieke ensembletheorie wordt hieruit een heel spectrum van fractale eigenschappen berekend, waaronder de fractale dimensie, de entropie, en de autocorrelatie. Dat spectrum van fractale eigenschappen wordt de ‘Gegeneraliseerde Fractale Dimensie’ (GFD) genoemd.

Een groot praktisch probleem is de bepaling van de GFD. Conventioneel gebeurt dat door de verzameling te overdekken met een collectie hyperkubussen, en dan bepaalde schalingseigenschappen van de overdekking te bestuderen terwijl de zijde van de kubussen naar lengte nul daalt. Niet alleen is het moeilijk zo’n overdekking te construeren voor de meeste verzamelingen, het is bovendien aangetoond dat er verscheidene nadelen kleven aan deze methode. Zo kan worden aangetoond dat deze methode consequent een te lage schatting levert voor dimensies hoger dan 2.6.

In dat verband komt een geheel andersoortig, en eveneens zeer recent, formalisme te hulp: ‘wavelets’ en ‘multi resolutie analyse’ (MRA). Wavelets zijn – zoals de naam al aangeeft – kleine ‘golfjes’: ze hebben integraal nul (vandaar: golf), en een beperkte compacte support (vandaar ‘golfje’). Geheel analoog aan Fourier-analyse is het mogelijk om afbeeldingen weer te geven als (oneindige) sommen van wavelets. MRA biedt een elegante methode voor een dergelijke decompositie. De prijs die daarvoor betaald moet worden is dat er nu behalve de spectrale componenten ook spatiële componenten zijn, zodat het aantal coëfficiënten feitelijk verdubbelt. MRA richt zich bij elke schaal van vergroting juist op die gebieden van het object waar deze schaal bijzonder relevant is. Maar dit is juist de eigenschap die we nodig hebben voor het overdekken van het fractale object met hyperkubussen. Het is mogelijk om wavelets te zien als een soort gegeneraliseerde hyperkubussen, en zodoende de MRA als een soort gegeneraliseerde overdekking van het object. Wavelets zijn derhalve bijzonder geschikt voor de analyse van fractale objecten. De laatste paar jaren is deze aanpak verder uitgewerkt, met name door Mallat en Hwang. Dit heeft geleid tot de ‘Wavelet-Transform Modulus Maxima’ (WTMM) methode. Met de WTMM-methode kan de GFD van een object efficiënt worden

berekend. Deze methode is recentelijk met succes toegepast om texturen te analyseren en te classificeren.

In hoofdstuk 3 worden al deze formalismen beknopt besproken, en waar nodig toegelicht met een voorbeeld. Allereerst wordt 'traditionele' Fourier-analyse toegepast. Hieruit kunnen slechts 'power-laws' gedistilleerd worden, maar geen fractale dimensies. Uiteindelijk wordt het multifractale wavelet formalisme toegepast op de analyse van scanprofielen en beelden van drukfouten. Daardoor wordt een beeld van een drukfout afgebeeld in een collectie getallen, namelijk de GFD. De GFD kunnen we dus zien als een specifieke 'featurevector'. In deze representatie blijken veel drukfoutklassen goed gescheiden te worden. Er zijn echter veel praktische problemen aan deze methode, met name de excessief lange rekentijden en het digitale karakter van de gebruikte beelden, die maar een beperkte vergroting toestaat.

Het aantrekkelijke van deze representatie is dat ze 'sterk' templaaf-onafhankelijk is, d.w.z. op geen enkele wijze de kennis van de gebruikte templaaf veronderstelt (waarbij we er van uitgaan dat deze zelf geen fractaal is). Bovendien is het – in principe – mogelijk om de GFD van de afbeelding te relateren aan het onderliggende fysisch-chemische drukkingproces. De fouten ontstaan door een combinatie van rheologische, mechanische, en chemische processen die derhalve ook de GFD van het doordoor ontstane patroon bepalen. Kennis van dit mechanisme zou het mogelijk maken om, uitgaande van de schatting van de GFD van het CCD-beeld, de relevante procesparameters te schatten, en derhalve het proces bij te sturen. Momenteel is een dergelijk idee echter volstrekt onhaalbaar.

We concluderen dat het idee van multifractale wavelet-analyse voor classificatie van drukfouten veel potentie heeft, maar om genoemde praktische redenen nog niet bruikbaar is.

En passant wordt in dit hoofdstuk ook een eigen generalisatie van MRA gepresenteerd, GWDA genaamd, en voorbeelden gegeven van de toepassing daarvan.

Hoofdstuk 4 AUTOMATISCHE CLUSTERINGSMETHODEN VOOR HOOG-DIMENSIONALE FEATURE-RUIMTEN MET SLECHT GESCHIEDEN KLASSEN

Dankzij met name hoofdstuk 2 kunnen we nu een drukfout als een punt in een hoog-dimensionale 'feature-ruimte' weergeven. Het blijkt echter dat verscheidene foutklassen in deze ruimte slecht gescheiden zijn. Bovendien zijn er relatief veel foutklassen, en is het wellicht mogelijk om met behulp van deze representatie, een andere, meer relevante foutklassen-taxonmie te ontdekken. Een belangrijke motivatie is bovendien dat we in hoofdstuk 5 een *interactief* classificatiealgoritme gaan beschrijven, zodat slechts een deel-verzameling van de feature-ruimte nodig is.

In dit hoofdstuk worden daarom verschillende clusteringparadigma's getest op hun bruikbaarheid voor deze ruimte. Directe clustering en classificatie van beelden met behulp van neurale netwerken blijkt vanwege de resulterende computationele complexiteit bezwaarlijk. De neurale netwerken die nodig zijn voor deze toepassing hebben bijzonder veel parameters. Daardoor zouden onrealistische hoeveelheden voorbeelden noodzakelijk zijn om deze parameters te trainen.

Onze aandacht gaat daardoor uit naar 'fuzzy clustering'. Dergelijke technieken, zoals Fuzzy C-Means (FCM) zijn sterke 'unsupervised' (dat wil zeggen dat de meetpunten niet gelabeld zijn) clusteringtechnieken. We stellen een aanvulling op FCM voor, door in plaats van bolvormige 'memberships-functies' ellipsoidale functies te gebruiken, die een betere benadering geven van de locale metriek van de klasse. Deze methoden noemen we Fuzzy Multi-Variate clustering (FMV). Dit resulteert in clustering die op zijn minst gelijkwaardige

partities van de feature-ruimte geeft, maar aanzienlijk sneller een resultaat bereikt. Derhalve is FMV ook meer geschikt voor meer-dimensionale ruimten dan FCM.

Een groot nadeel van clusteringmethoden, inclusief FCM en FMV, is dat zijn enige veronderstellingen vereisen van het aantal of de verdeling van de klassen over de feature-ruimte. Daarom stellen we een automatisch clusteringalgoritme voor, genaamd *iteratieve FMV cluster analyse*, gebaseerd op FMV, die zelfstandig het aantal significante klassen in de data bepaalt middels successievelijke splitsing of samenvoeging van klassen.

Tenslotte passen we clusteringtechnieken toe op de twee representaties die gebaseerd zijn op de CID-transformatie uit hoofdstuk 2. In het eerste geval laten we zien hoe de SOM-clusteringtechniek gebruikt kan worden bij een eenvoudig model van twee soorten drukfouten, en voor de schatting van de grootte van de verstoring. In het tweede geval laten we zien hoe iteratieve FMV cluster analyse gebruikt kan worden voor de partitionering van een CID-gebaseerde representatie, die daardoor zeer geschikt wordt om te dienen als preclassificatie.

Hoofdstuk 5 INTERACTIEVE CLASSIFICATIE VOOR HOOG-DIMENSIONALE, SLECHT-GESCEIDEN KLASSEN EN RUIS

Nu hebben we drukfoutanalyse teruggebracht tot de classificatie van een actuele meting van feature-waarden in één van de – van te voren geïdentificeerde – foutklassen. Dit kan betekenen dat eerst alle mogelijke metingen worden verricht, waarna een simpele toewijzing in de feature-ruimte volgt. Hierdoor zou de classificatie zeer tijdrovend en rekenintensief zijn. Bovendien is het veelal onnodig om alle metingen te verrichten, omdat gedurende het proces reeds duidelijk is geworden wat de waargenomen foutcategorie is. Mede geïnspireerd door het ‘actief zien’ bij levende wezens kiezen we voor een andere aanpak. In dit hoofdstuk stellen we een interactieve methode voor om gelijktijdig te kunnen classificeren en meten. We noemen dit ‘interactieve classificatie’. Belangrijkste probleem hierbij is om, gebaseerd op de huidige metingen en resulterende veronderstellingen, de ‘beste’ volgende meting te kiezen. De aanpak die we kiezen is gebaseerd op functionale optimalisatie. We definiëren een aantal functionalen die gebaseerd zijn op de scheiding van klassen. Daartoe moet een eerst zinvolle metriek in de feature-ruimte gedefinieerd worden. De meest-gebruikte afstandsmaat is de ‘Mahalanobis-afstand’, maar deze is niet-symmetrisch voor klassenafstanden: $\text{afstand}(\text{klasse1}, \text{klasse2})$ is i.h.a. niet gelijk aan $\text{afstand}(\text{klasse2}, \text{klasse1})$. Daarom komen we met andere voorstellen, zoals de ‘geometrische’ afstand. In dezelfde zin definiëren we de relevantie van een bepaalde featureparameter voor een bepaalde foutklasse. Met behulp van deze afstandsmaten definiëren we nu functionalen. Optimalisatie van deze functionalen leidt tot de featureparameter die de meeste scheiding van de klassen geeft, en in die zin de meest zinvolle meting is. Door de actuele hypothese – weergegeven door de kansverdeling over de foutklassen – te integreren in deze functionaal maken we dit proces dynamisch. Zodoende kiezen we de featureparameter die, gegeven de huidige hypothesen, het meeste perspectief biedt om tussen de concurrerende hypothesen te kiezen. Van belang is dat gedurende het redeneerproces aanvankelijk weinig gewicht wordt toegekend aan een hypothese, maar later geleidelijk aan steeds meer. Dit wordt tot uitdrukking gebracht in de z.g. ‘dynamiciteits-exponent’. Vervolgens wordt de aandacht gevestigd op het probleem om ongelijkaardige informatie te integreren. Hierbij moet worden gedacht aan de grote hoeveelheid sensorinformatie die beschikbaar is, zoals betreffende viscositeit, temperatuur, en mechanische druk. Gekozen wordt voor een representatie als normale multivariate

verdelingen, de zogenaamde Gausische mixtures. Veel nadruk krijgt de controle van het redeneerproces. Zo worden enkele statische en dynamische stopcriteria gedefinieerd. Hierbij slaat 'dynamisch' op het feit dat deze de geschiedenis van de iteratie betreft bij de beslissing tot beëindiging van de iteratie. Hierbij blijkt dat in het geval van een stopcriterium met een constante 'threshold' een optimale waarde berekend kan worden voor die threshold in de zin van maximale slaagkans bij minimale iteratielengte.

Al deze onderwerpen tezamen vormen de ingrediënten voor een geïntegreerde aanpak voor simultaan *meten* en *classificeren*, genaamd: *InterActive Sensing and Classification (IASC)*. Doel van *IASC* is de 'on-line' classificatie van een object, gebaseerd op geselecteerde sensor-metingen. De methode kan gedefinieerd worden als een iteratief algoritme, of als een geïtereerde afbeelding op de ruimte van hypothesen, waarbij de meting 'slechts' een parameter is. Voor onze aanname van Gausisch verdeelde klassen kan deze afbeelding verder worden uitgewerkt.

Een centrale plaats neemt de convergentie en stabiliteit van de *IASC*-methode in. Daartoe worden eerst enkele maatstaven voor de prestatie gedefinieerd: de *kwaliteit* ' q ' van de conclusie (die 1 is voor éénduidige conclusies, en 0 voor meerduidelijke conclusies), de *slaagkans* ' s ' van het algoritme (die 1 is als de correcte foutklasse wordt gevonden en anders 0), en de *relatieve lengte* ' T ' van de iteratie (dat is het aantal verrichte metingen t.o.v. het totaal aantal mogelijke metingen, dus eveneens tussen 0 en 1). Zoals reeds eerder vermeld, kan de actuele hypothese weergegeven worden als een kansverdeling over de K mogelijke foutklassen. De actuele hypothese kan dus gerepresenteerd worden door een vector in \mathbb{R}^K , en, daar de kansmaat voor iedere afzonderlijke klasse in het interval $[0,1]$ ligt, meer specifiek als een punt in een K -dimensionale hyperkubus $[0,1]^K$. De hoekpunten van deze hyperkubus corresponderen met concreet voorkomende foutklassen. De hele *IASC*-iteratie correspondeert zodoende met een baan in deze hyperkubus. De *IASC*-iteratie convergeert derhalve als die baan eindigt in een hoekpunt. De actuele *meting* daarentegen is een vector in de feature-ruimte, waarvan gedurende de iteratie steeds meer componenten 'bekend' worden. Die feature-ruimte is opgedeeld in K cellen, die corresponderen met de K bekende foutklassen. Het centrale vermoeden is nu dat als de meting in een bepaalde cel ligt, de *IASC*-iteratie naar de betreffende foutklasse convergeert met een kwaliteit q die bepaald wordt door de afstand van de meting tot het centrum van de corresponderende cel. Deze afstand is tevens een maat voor de relatieve ruis in de meting.

Verscheidene wegen worden gevolgd om deze veronderstelling te bewijzen. In sectie 5.6.5 wordt aangetoond dat de *IASC*-iteratie een contractie is, daar de Jacobiaan monotoon naar nul nadert. Alle convergerende iteraties zijn contracties. Echter, niet alle contracties corresponderen met convergerende iteraties, bijvoorbeeld bij meervoudige convergentiepunten of bij chaotische gedrag nabij 'strange attractors'. In sectie 5.6.6 worden drie scenario's nader onder de loep genomen. i. Als de meting identiek is aan het centrum van een cel dan convergeert de *IASC*-iteratie naar de correcte conclusie. ii. Als de meting erg dicht bij het centrum van een cel ligt, dan convergeert de iteratie eveneens. Dichtbij blijkt hier te zijn: dichter bij dan de wortel uit de kleinste eigenwaarde van de covariantiematrix van de bijbehorende foutklasse. Tenslotte: iii. de meting ligt niet 'dicht' bij een cel-centrum. Naarmate de Euclidische afstand tot het centrum toeneemt, zullen er featureparameters zijn waarvoor de meting dichter bij een centrum van een andere cel ligt. Deze featureparameters zijn dan slecht gescheiden t.o.v. de anderen, en hebben dus een lage selectiekans bij de functionale parametersselectie die ten grondslag aan *IASC*. Desalniettemin, als de fractie van 'foute' parameters toeneemt, neemt de kans op een verkeerde beslissing ook toe.

In sectie 5.7 worden de dynamische eigenschappen van de *IASC*-iteratie nader bestudeerd. Eerst bestuderen we de evolutie van de klasse-waarschijnlijkheden gedurende de iteratie. We definiëren twee eenvoudige kengetallen: de *eindwaarde* en de *gemiddelde stijging* van deze

klasse-waarschijnlijkheden. Door middel van automatische clustering (NB: met *iterated FMV* uit hoofdstuk 4) van een groot aantal observaties worden vier typen evolutie onderscheiden. Deze vier typen kunnen gerelateerd worden aan de relatieve onderlinge ligging van de clusters. *Nabije* clusters zorgen voor enige 'verwarring' bij de evolutie van de klasse-waarschijnlijkhedenfunctie gedurende de iteratie, en kunnen op een relatief laat moment de 'balans' nog laten omslaan. Sommige klassewaarschijnlijkheden convergeren naar een waarde ergens tussen nul en een in. Dit inzicht leidt tot een bespreking van de rol van *diffuse klassen* en *gemengde evenwichtspunten*. Gemengde evenwichtspunten zijn punten in de feature-ruimte die 'onbeslisbaar' zijn. Onbeslisbaar betekent hier dat de *IASC*-iteratie niet naar een éénduidige conclusie convergeert. In het geval van een oneindig lange iteratie zijn dit de punten op de separatrix tussen twee klassen. Daar echter de *IASC*-iteratie eindig lang is, zullen punten nabij de separatrix, met name bij diffuse klassen, echter ook onbeslisbaar zijn. In de volgende subsecties wordt iets verteld over de schatting van de gehele meting, gedurende de *IASC*-iteratie, alsmede over de betrouwbaarheid daarvan. Daarop gebaseerd wordt de kansmaat bepaald dat de actuele hypothese wordt verworpen op grond van een nieuwe meting, gedurende de *IASC*-iteratie. Aangevoerd wordt dat deze kans quasi-exponentieel afneemt gedurende de iteratie.

Van grote invloed zijn de stop-criteria op de prestatie van het *IASC*-algoritme. Deze worden nader bestudeerd in sectie 5.7.5. Middels een *mean-field approach* wordt een theoretisch model verkregen dat de relatie tussen de gemiddelde slaagkans s en de relatieve iteratielengte T voorspelt.

Tenslotte wordt in sectie 5.7.6 een aantal modellen gepresenteerd voor de evolutie van de dynamiciteits-exponent. Deze bepalen de invloed van de actuele hypothese op de feature-parameter selectie.

We concluderen dat het *IASC*-algoritme een raamwerk biedt voor interactieve classificatie, die onder bepaalde omstandigheden tot de juiste conclusie leidt, terwijl maar een klein deel van alle mogelijke metingen is verricht. Dit raamwerk is niet alleen toepasbaar binnen computer vision, maar ook in alle gevallen waar diagnose en meting samengaan, zoals in chemische analyse, medische diagnose, en autonome robots.

Hoofdstuk 6 NUMERIEKE EXPERIMENTEN MET *IASC*

In dit hoofdstuk worden tal van numerieke experimenten met het *IASC*-algoritme uitgevoerd. Dit om inzicht te krijgen in de werking van *IASC* en ter vergelijking met andere methoden. Bovendien kunnen zo enkele theoretische voorspellingen uit hoofdstuk 5 worden getoetst. Om de *performantie* te kwantificeren meten we de reeds genoemde slaagkans s , kwaliteit q , en relatieve iteratielengte T . Grootheden die de *complexiteit* van het classificatieprobleem weergeven zijn de gemiddelde genormaliseerde afstand $\langle d \rangle$ tussen de klassen, en de relatieve ruis v in de meting – die een maat is voor de afstand van de meting tot het centrum van de foutklasse in de featureruimte. *Controle parameters* in het *IASC*-algoritme zijn de gekozen optimalisatie-functionaal, de representatie van de klassewaarschijnlijkheden (in ons geval Gausisch), de ontwikkeling van de dynamiciteits-exponent, en het gebezigde stopcriterium. Als eerste worden verschillende optimalisatie-functionalities getest. Als maatstaf voor de vergelijking dienen twee uitersten: i. uitputtend alle metingen verrichten, en ii. random selectie van metingen. De conclusie is dat bij overlappende klassen ($\langle d \rangle < 1$) of enige ruis ($v < 0.4$), *IASC* beter presteert dan random of uitputtende parametersselectie. Tevens wordt een enkel experiment met multi-criteria-functionalities beschreven.

Vervolgens worden enkele modellen voor de evolutie van de dynamiciteits-exponent getest. Daarbij blijkt dat er grote verschillen zijn tussen scenario's waar deze constante waarde nul

heeft, maar dat verrassend genoeg er verder weinig verschil valt te meten tussen de specifieke evolutiemodellen. Tenslotte worden verscheidene statische en dynamische stopcriteria vergeleken. In sectie 6.6.4 wordt zodoende de theoretisch voorspelde relatie tussen slaagkans en iteratielengte voor constante threshold geverifieerd, alsmede de theoretisch voorspelde optimale waarde voor de threshold.

De algemene conclusie betreffende interactief classificeren met *IASC* kan bondig worden samengevat als:

- geringe klassenoverlap en weinig ruis: *alle* methoden werken
- sterke klassenoverlap of veel ruis: *IASC* werkt beter dan random en uitputtend
- sterke klassenoverlap en veel ruis: *niets* werkt meer

Hoofdstuk 7 KWALITEITSGESTUURDE BEDRUKKINGS-PROCESSEN.

In dit hoofdstuk keren we terug naar ons hoofdthema; de kwaliteitssturing van drukprocessen. In dit hoofdstuk komen alle ingrediënten terug die eerder besproken zijn. Dit hoofdstuk behandelt de resultaten van het Europees onderzoeksproject *IntelPadPrint*, waarbinnen deze studie grotendeels is verricht. Na een korte beschrijving van de doelstellingen, samenstelling en uiteindelijke behaalde resultaten van dit project wordt een beschrijving gegeven van het probleemgebied: industriële bedrukkingsprocessen voor massaproductie. In een aparte paragraaf worden de relevante featureparameters voor bedrukkingsfouten besproken. Vervolgens worden de twee gerealiseerde prototypen besproken.

Het eerste prototype, PT1 genaamd, was gebaseerd op scananalyse en een model voor lineaire correlatie tussen featureparameters en foutklassen. Een eenvoudig model regelde de ruimtelijke exploratie van het beeld naar fouten en de integratie van de conclusies. Deze iteratie convergeerde meestal binnen zo'n honderd stappen naar een resultaat. De gemiddelde performantie van dit algoritme bedroeg zo'n $79 \pm 22\%$. In feite was dit een primitieve voorganger van het *IASC*-algoritme.

Het tweede prototype, PT2, was uitgerust met het *IASC*-algoritme (hoofdstuk 5). Maar tevens werd gebruik gemaakt van een preclassificatie-methode van een representatie van het beeld gebaseerd op de CID-transformatie (hoofdstuk 2). Sommige van de featureparameters werden met behulp van fractale wavelet analyse berekend (hoofdstuk 3). Bovendien was de partitie van de feature-ruimte verricht middels *iterated FMV* (hoofdstuk 4). Een *intelligent camera system* (ontwikkeld door de Universiteit van Birmingham) leverde de CCD-beelden van overwegend redelijke kwaliteit. De evaluatie van dit systeem betreft drie gradaties: i. de identificatie dat een drukfout optreedt, ii. de genoemde preclassificatie van het beeld, iii. het resultaat van het *IASC*-algoritme. Voor bruikbare beelden, zo'n 77% van het totaal, was de performantie van i: 99%, van ii (preclassificatie): 97% en van iii (*IASC*): 95%. De laatste werd voornamelijk bepaald door de kwaliteit van de feature-extraction. De conclusies betreffende PT2 zijn dat *IASC* goed functioneert, maar erg gevoelig is voor de beeldkwaliteit. Daarom moet in een praktische uitwerking van dit prototype met name de beeldkwaliteit sterk verbeterd worden.

De belangrijkste conclusie van onze studie is dat onze aanpak, mede gebaseerd op interactieve classificatie en fractale wavelet analyse, een goed raamwerk biedt voor directe kwaliteitssturing met behulp van 'computationele visie', maar dat meer onderzoek noodzakelijk is om dit concept op een niveau te brengen die noodzakelijk is voor toepassing in de industriële praktijk.